

Machine Learning en minería

# Predicción del aumento del consumo específico de energía en Molinos SAG

**Juan Sepúlveda Cruz**  
[juansepulveda@jhg.cl](mailto:juansepulveda@jhg.cl)  
Ingeniero I+D  
JHG Ingenieria





35  
años

JHG es una empresa especializada en el diagnóstico y optimización de procesos termo-energéticos y ambientales, apoyando a sus clientes en la optimización del negocio y el cumplimiento de las exigencias normativas que aplican a la Minería e Industria Chilena.


Nuestro objetivo es contribuir al desarrollo de una minería sustentable a través de la optimización energética de los procesos mineros, complementado con herramientas innovadoras que permiten incrementar la productividad de las personas.

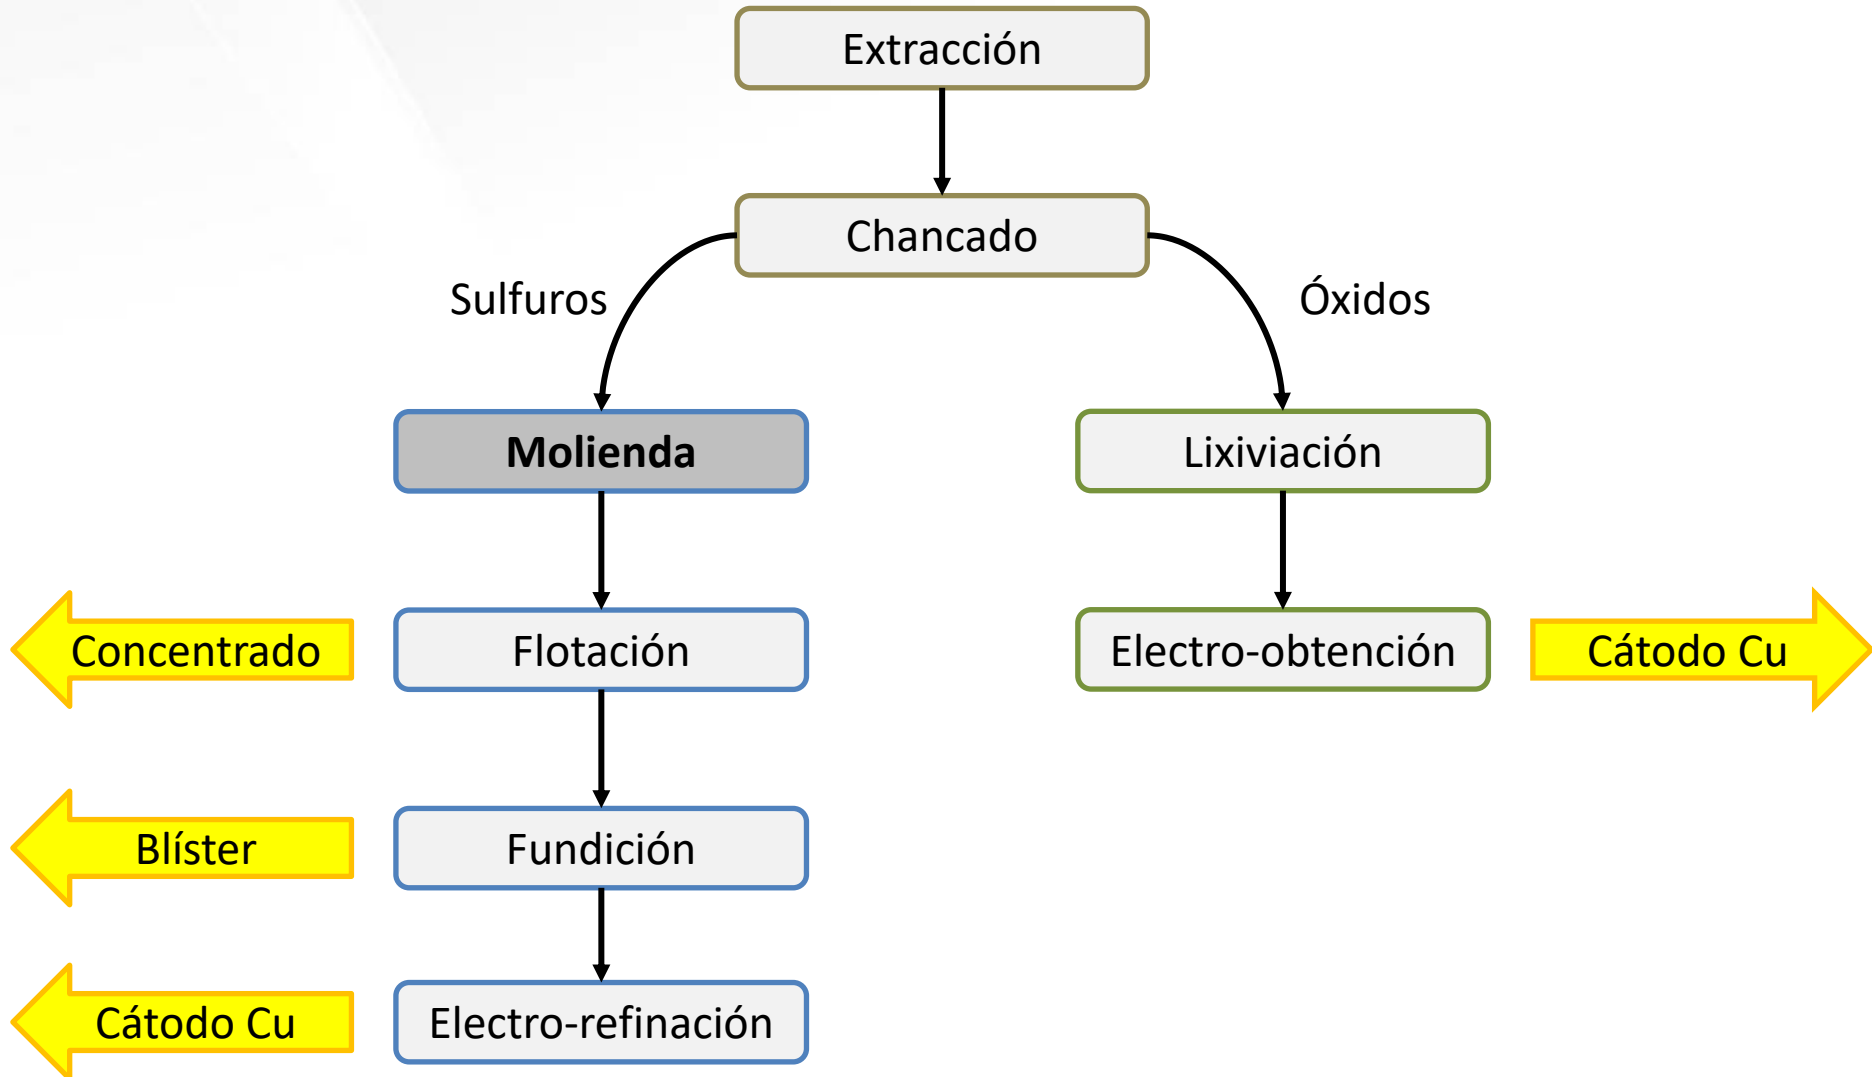
JHG cuenta con más de 35 años de experiencia, más de 100 proyectos de Eficiencia Energética realizados y un equipo multidisciplinario de más de 90 técnicos y profesionales en áreas de la Ingeniería, mantención de equipos térmicos, desarrollo de Capital Humano y Medición de emisiones.




- Contexto: Molinos SAG
- Machine Learning y abstracción del problema
- Datos: Limpieza y preprocesamiento
- Modelación y métricas de desempeño
- Resultados
- Otras aplicaciones



# Contexto – Molinos SAG







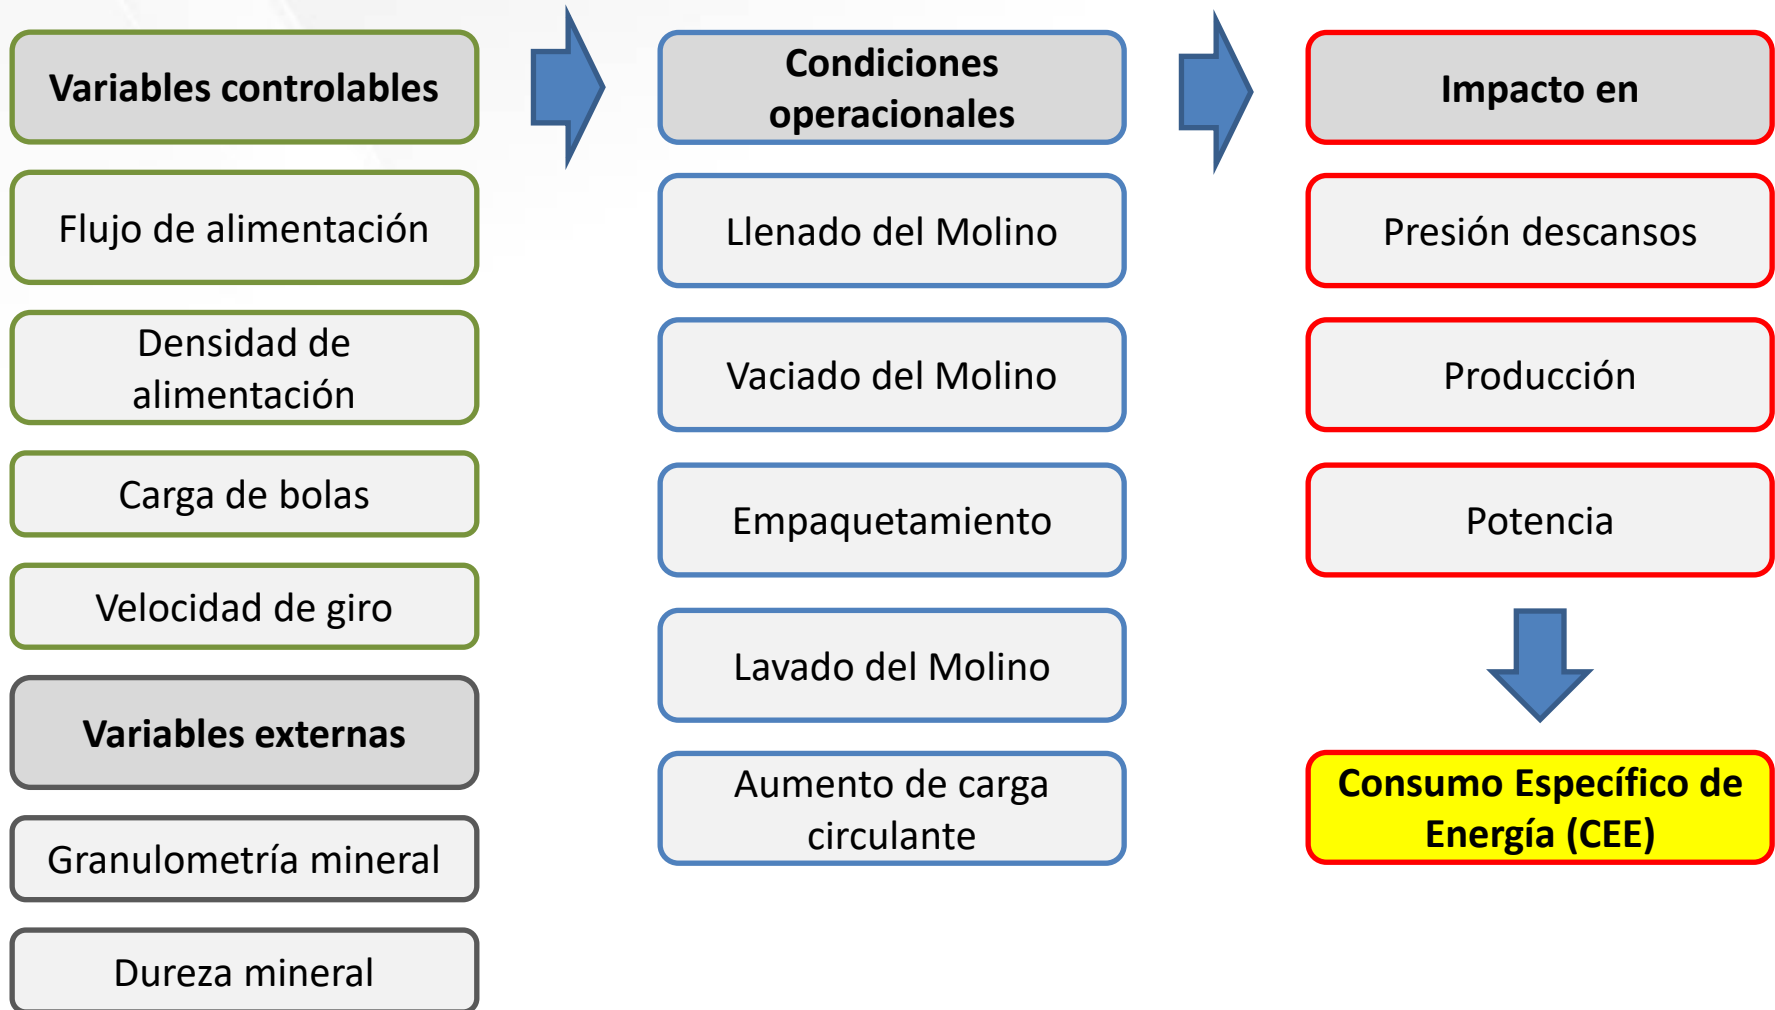


## Un SAG promedio en Chile

Diámetro	11 - 12 metros
Producción	2.000 a 3.000 t/h
Potencia	20 MW
Consumo Específico	5 a 8 kWh/ton

## Todos los SAG de Chile

Consumo energía	8.500 MWh/día
% Consumo país	≈ 5%
Costo en energía	231 MMUSD/año
Costo unitario	9,6 MMUSD/año





Los molinos SAG son unos de los equipos de **mayor consumo de energía** eléctrica del proceso minero, por lo que resulta indispensable que su operación sea **eficiente** desde el punto de vista energético.

La **operación eficiente** de un molino SAG depende del adecuado conocimiento y manejo de las variables de control que lo gobiernan, como por ejemplo: el flujo de alimentación, granulometría, dureza, velocidad de giro, etc.



Sin embargo, la gran cantidad de variables que afectan el CEE del Molino resulta en **una gran dificultad** para determinar si la tendencia de alguna de ellas podría o no influir en el **aumento del Consumo Específico sobre un límite** que se considere apropiado.

Con el objetivo de **evitar eventos** donde el Consumo Específico de Energía del molino SAG **sobrepase un límite o meta establecida**, es conveniente desarrollar un sistema predictivo capaz de **anticipar** el comportamiento del CE dadas las condiciones de operación del molino.




Esto requiere modelar correctamente la compleja interacción entre cada una de las variables de operación y su efecto en el CEE, tarea para lo cual resulta apropiado considerar el enfoque de modelación utilizando técnicas de Machine Learning.

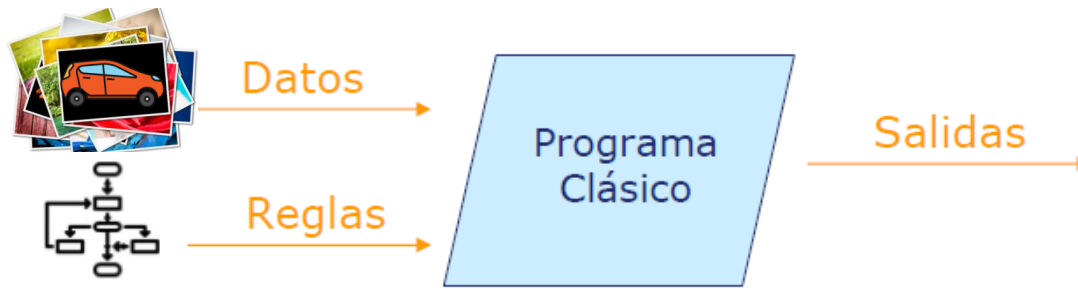
# Machine Learning y abstracción del problema



- Problema:



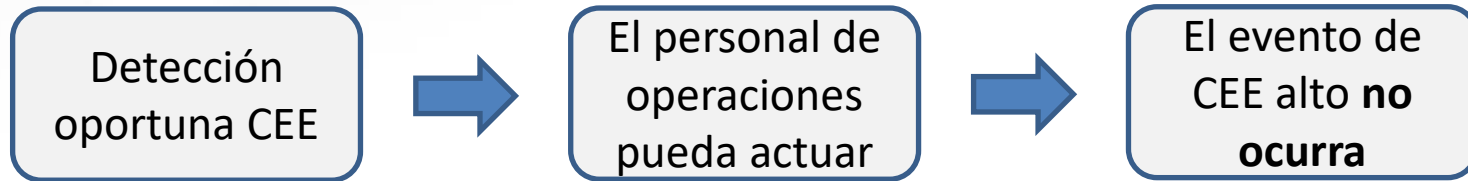
- Enfoque clásico (**aplicar** reglas conocidas a los datos):




- Machine Learning (**aprender** reglas desde los datos):



- Objetivo: Ahorrar energía
- Medio:



- Problema:



- Machine Learning:



## Hipótesis:

Durante un cierto tiempo previo a que el Consumo Específico se incremente, ocurren fenómenos físicos en el Molino SAG, que se reflejan en sus datos de operación y que un algoritmo es capaz de caracterizar.

## Abstracción:


Modelar es decirle al algoritmo: “quiero que aprendas a identificar **un fenómeno**”.

- **Fenómeno** = Lo que le pasa a las variables del SAG **X tiempo** antes de que el CEE se dispare.
- **X tiempo** = Otra incógnita, que representa el tiempo en que este fenómeno se manifiesta de mejor manera.

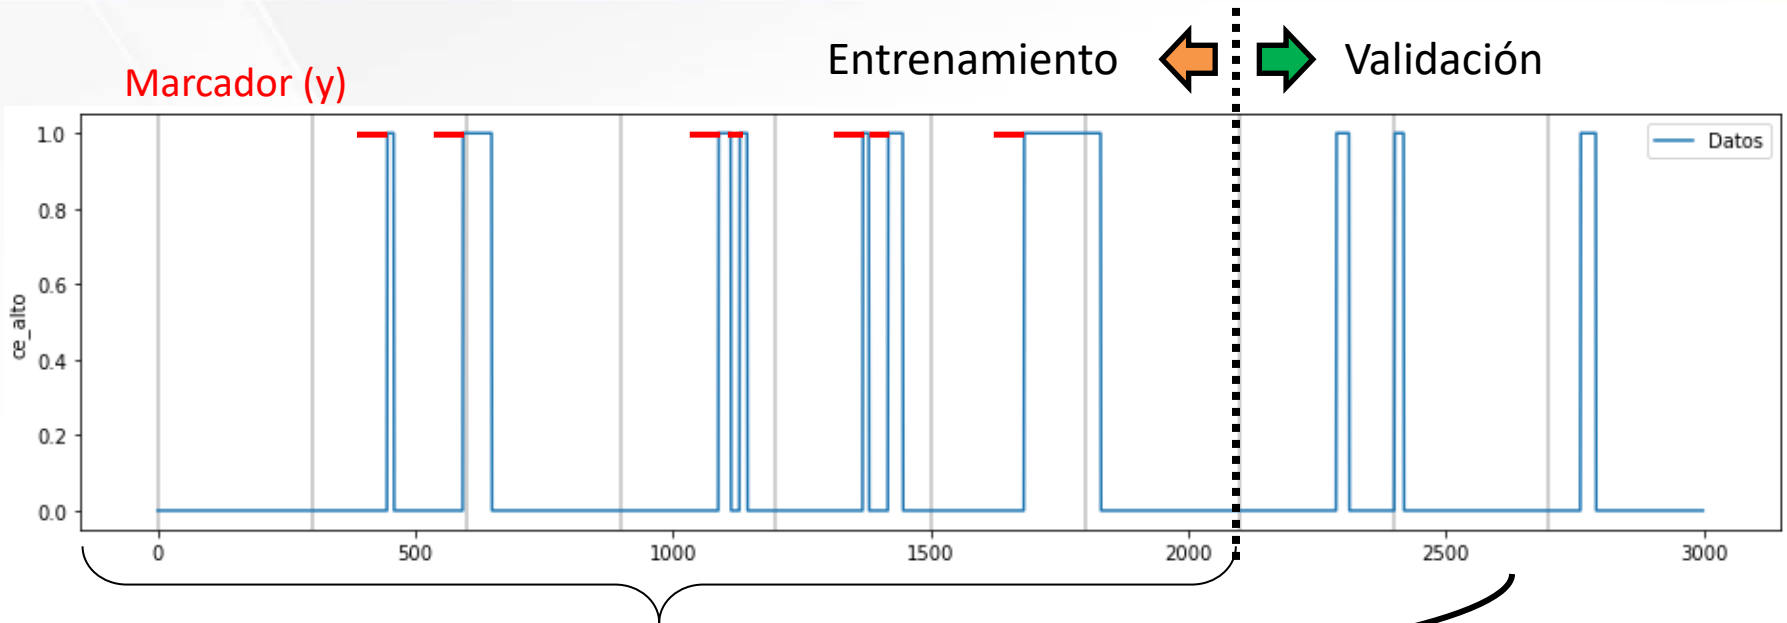
Tiempo	Potencia	Toneladas	...	CEE	CEE alto
1	4896	921	...	5,3	0
2	5678	752	...	7,6	1
...	...	...	...	...	...





Gráfico temporal para el **Consumo Específico Alto**



# Machine Learning – Abstracción del problema




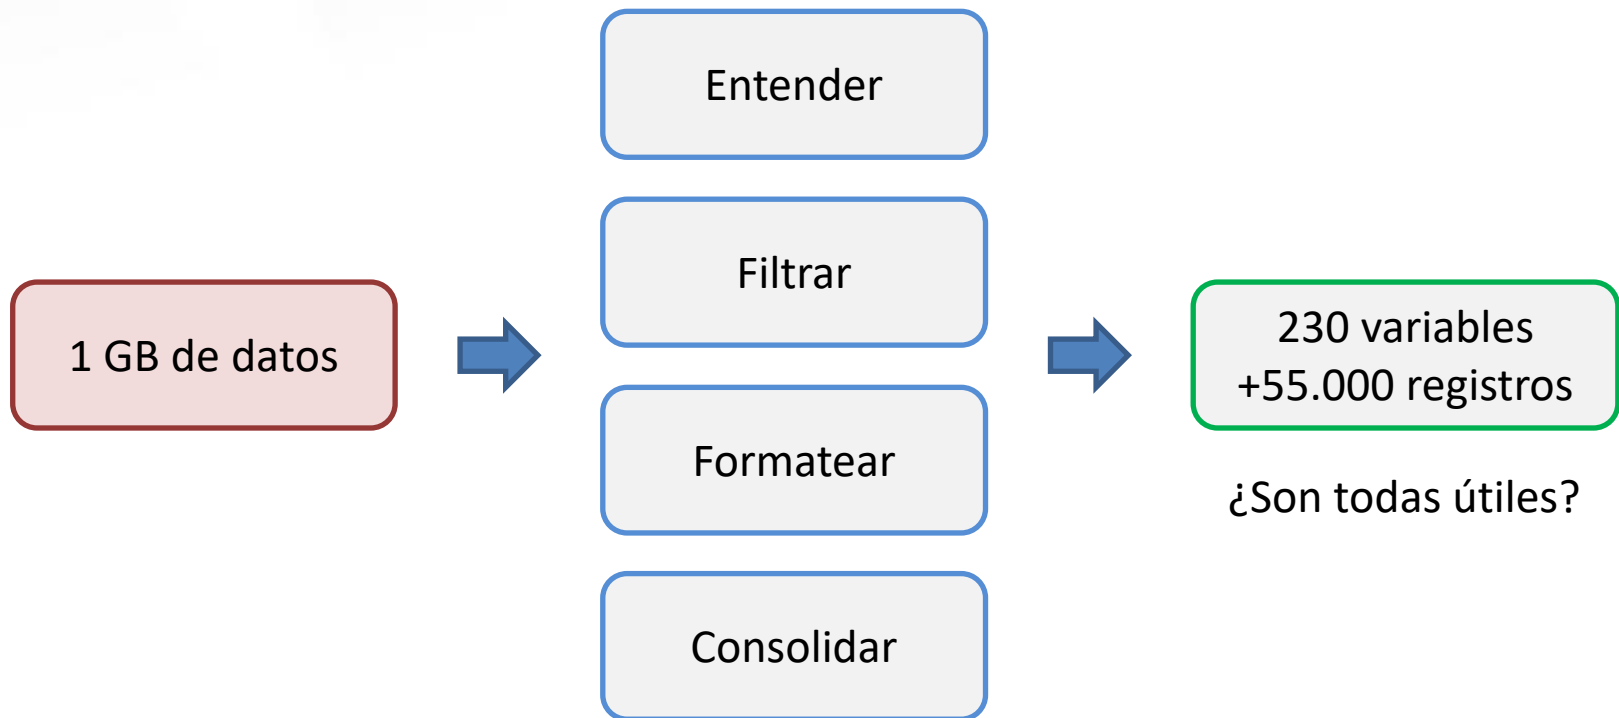
Modelo:  $y = f(x_1, \dots, x_n)$







# Datos: Limpieza y preprocesamiento


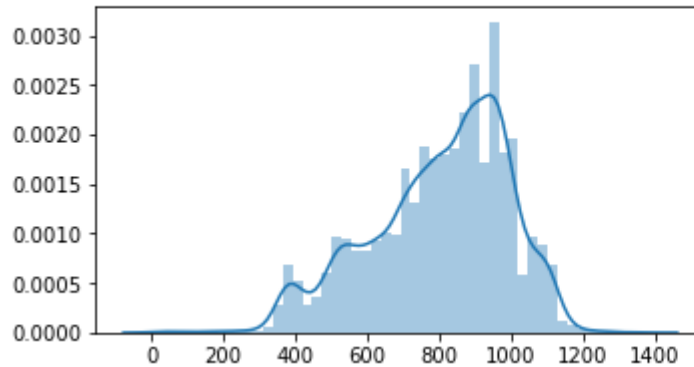




























Variable: Potencia motores SAG



Variable: Tonelaje Correa 1-1




# Limpieza – Inspección visual



230 Variables



200 Variables





55.000 registros




46.000 registros


# Limpieza – Suavizado con media móvil




# Procesamiento – Cálculo del CEE



Consumo Específico SAG





Potencia SAG




Toneladas ingreso a SAG


```
#Graficos de la distribucion del CE  
graf_var(df_join, 'CE_calculado')
```

Variable: CE\_calculado







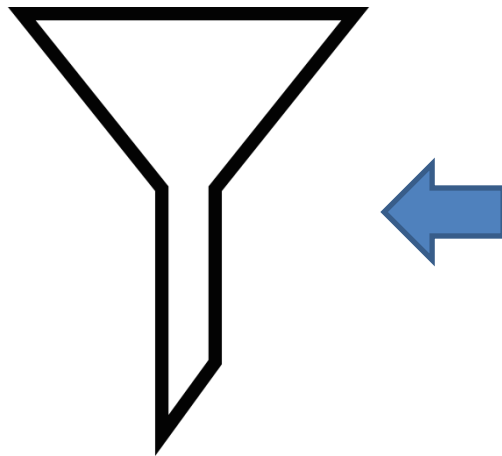


Alta dispersión del  
Consumo Específico




Dificultad para implementar  
enfoque analítico

230 Variables




19 Variables

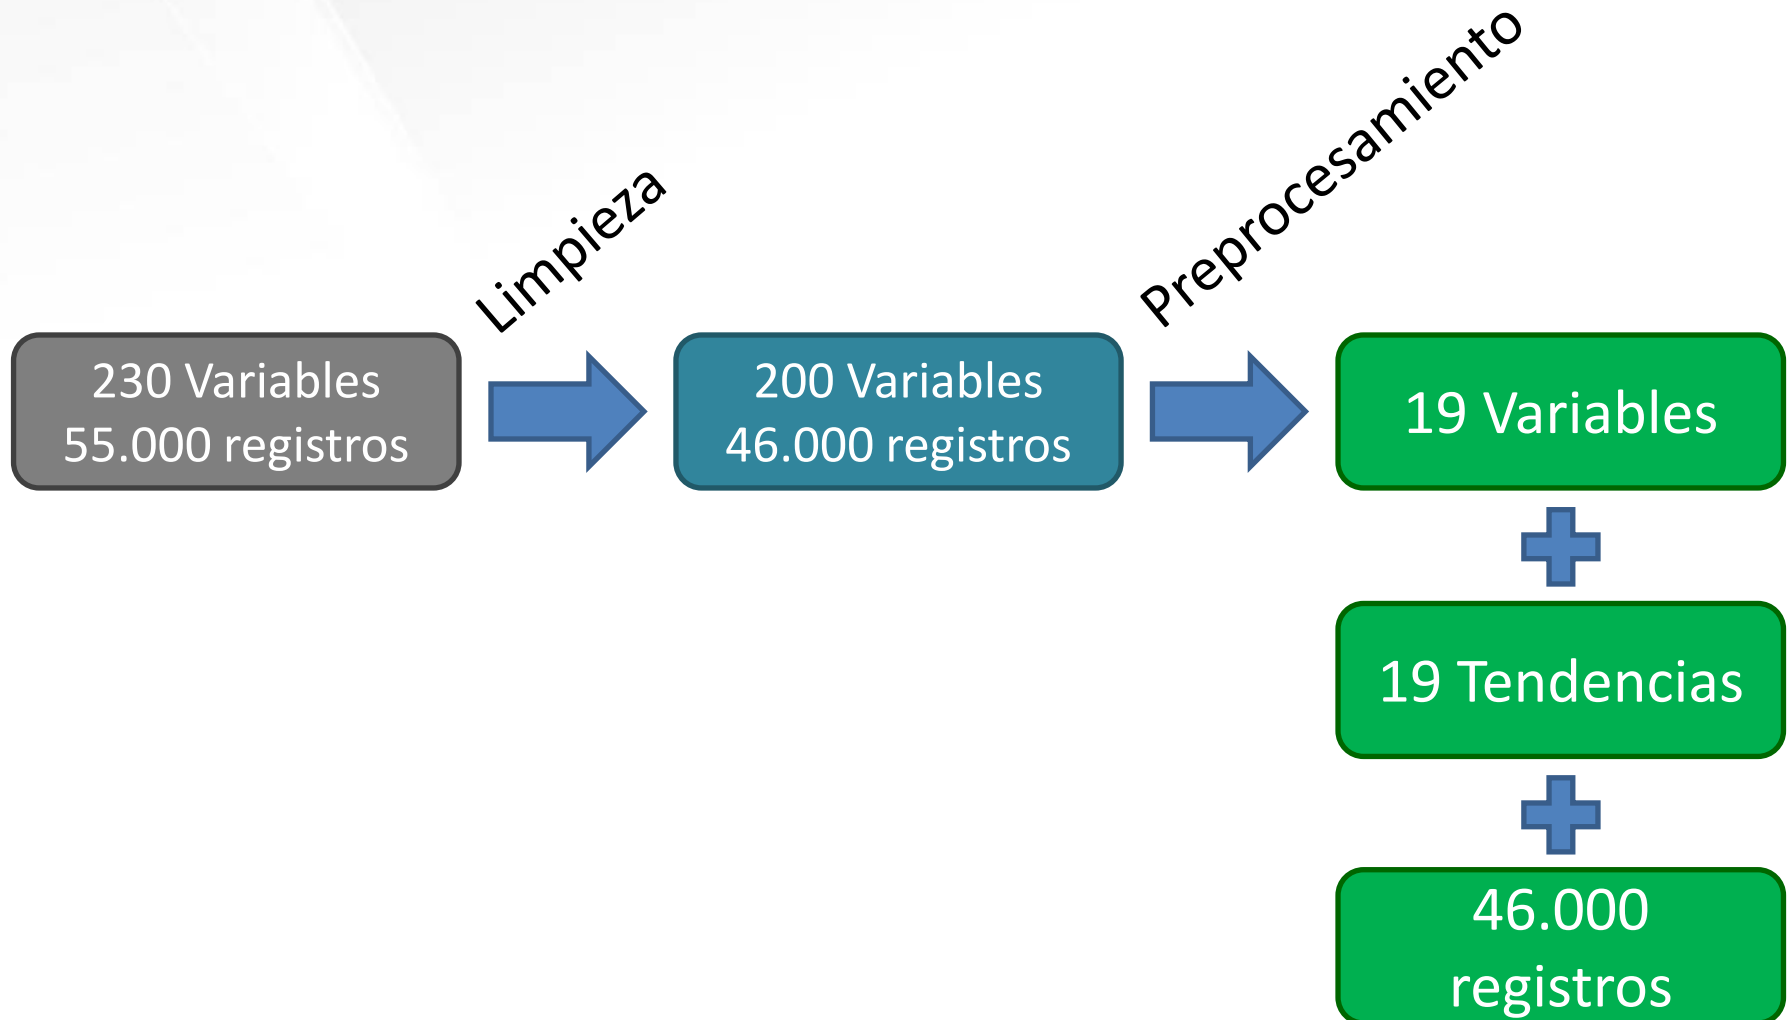
- Búsqueda de correlaciones con la variable objetivo (CEE).
- Objetivo: descartar variables muy poco correlacionadas con el CE.
- Correlación de Pearson  $> 0,3$  se mantienen para el modelo.




Potencia  
SAG



Derivada



# Modelación y métricas de desempeño



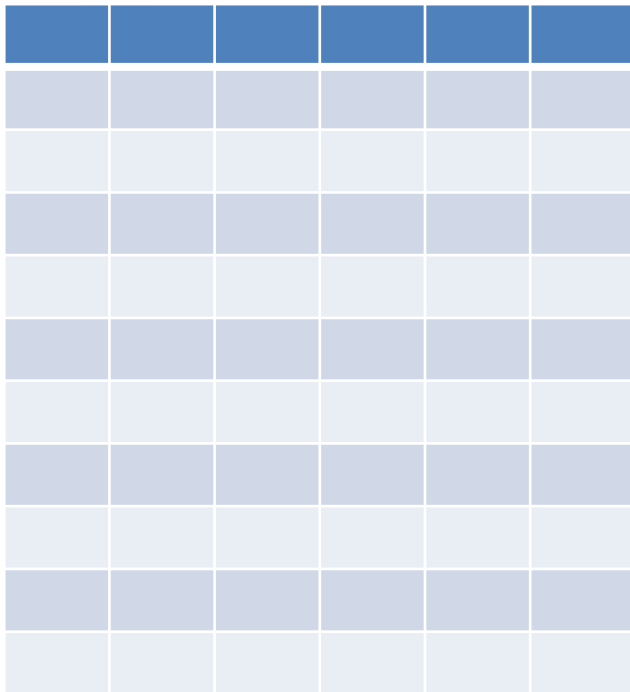
Seleccionar un *algoritmo* de Machine Learning

Seleccionar los datos de *entrenamiento*

Entrenamiento del modelo  
(minimización de función de error)

Evaluar desempeño del modelo con los datos de *validación*


19 columnas (variables) + 19  
columnas (tendencias) x  
46.000 registros minutaes  
(32 días de datos)



Entrenamiento:  
36.000 registros minutaes  
(25 días de datos)

Validación:  
10.000 registros minutaes  
(7 días de datos)





Tratar de no equivocarse



*Precisión* =

$$\frac{\text{Verdaderos positivos}}{\text{Total predicciones}}$$

$$= \frac{2}{4} = 50\%$$

Tratar abarcarlo todo




*Recall* =

$$\frac{\text{Verdaderos positivos}}{\text{Reales positivos}}$$

$$= \frac{2}{3} = 67\%$$

Alta Precisión  
Bajo Recall



Tratar de no equivocarse



*Precisión* =


$$\frac{\text{Verdaderos positivos}}{\text{Total predicciones}} = \frac{1}{1} = 100\%$$

Tratar abarcarlo todo



*Recall* =

$$\frac{\text{Verdaderos positivos}}{\text{Reales positivos}} = \frac{1}{3} = 33\%$$



Tratar de no equivocarse

*Precisión* =

$$\frac{\text{Verdaderos positivos}}{\text{Total predicciones}} = \frac{3}{12} = 25\%$$

Tratar abarcarlo todo

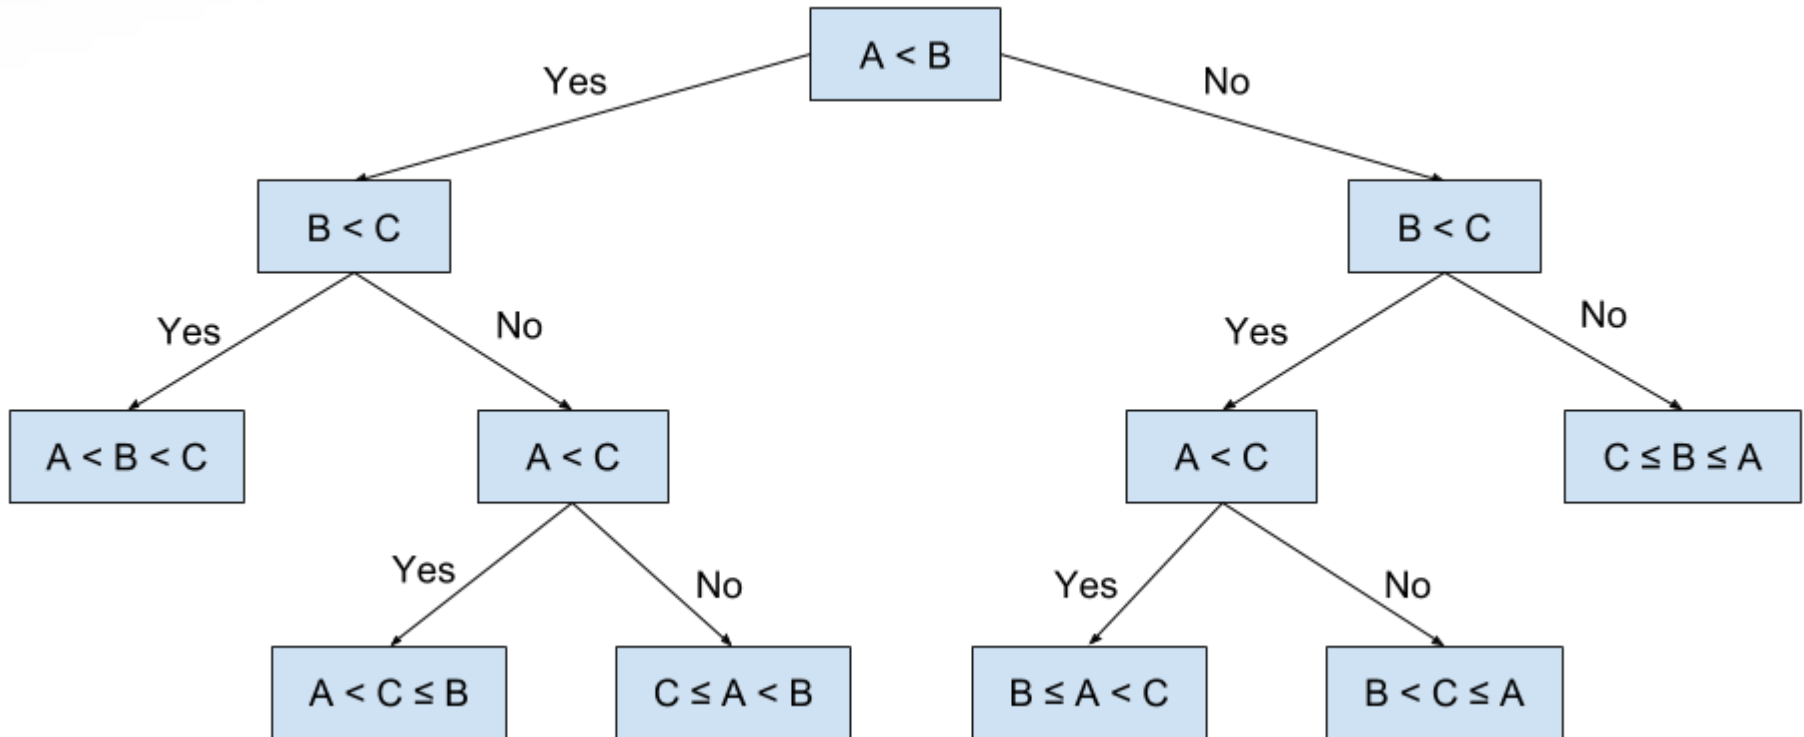
*Recall* =

$$\frac{\text{Verdaderos positivos}}{\text{Reales positivos}} = \frac{3}{3} = 100\%$$


*Decision Tree*




*Random Forest*



# Resultados







Caso	Minutos	Precisión	Recall
1	5	1	0,1
2	<b>15</b>	<b>0,5</b>	<b>0,7</b>
3	30	0,3	0,7



- Datos de Validación: 10.080 registros (7 días)
- Eventos de Consumo Específico Alto: 29



Datos de  
validación






Modelo entregado por  
el algoritmo de ML

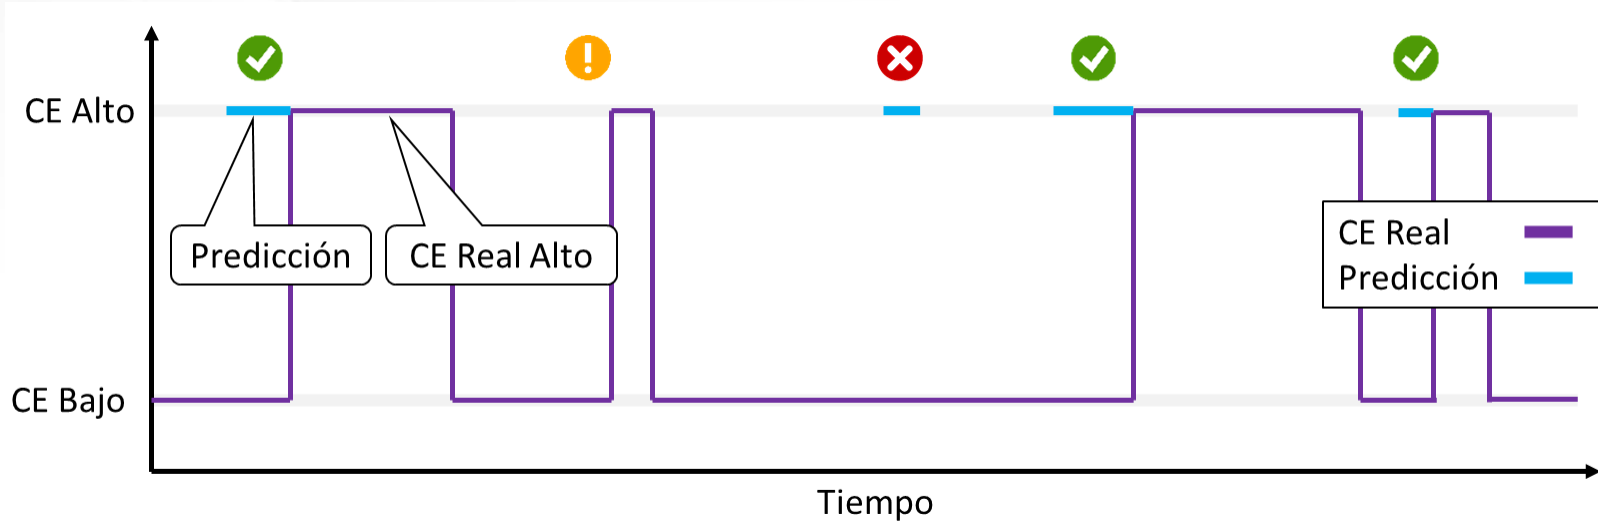


Predicciones

# Resultados – Ejemplo de predicción bruta








Eventos de CE alto	29
Predicciones realizadas	33
✓ True Positive (TP)	24
✗ False Positive (FP)	9
! False Negative (FN)	5

<b>Precisión</b>	<b>73%</b>
<b>Recall</b>	<b>83%</b>

# Resultados – Variables utilizadas en el Modelo



Descripción	tipo	valor	
Tonelaje Correa	variable	8,9%	
Presión Descansos SAG	tendencia	7,6%	
Consumo específico	tendencia	6,1%	
Indicador de Consumo especifico alto	variable	5,0%	
Consumo específico	variable	4,9%	
Potencia SAG	variable	4,4%	
Corriente bomba Alimentación Ciclón	variable	3,2%	
Densidad alimentación Ciclón	variable	3,0%	
%Sólidos alimentación SAG	variable	2,9%	
Presión Descansos SAG	variable	2,9%	



	CE alto
	Predicho
	No predicho

	Semana testeo	Proyección anual
Energía consumida [MWh]	2.967	154.284
Energía eventos de CE alto [MWh] <sup>1</sup>	48,4 (1,63%)	2.514
Energía eventos predichos [MWh] <sup>2</sup>	47,2 (1,59%)	2.453
Ahorro por eventos predichos [USD]	3.774	196.249


<sup>1</sup>: Energía acumulada en eventos de Consumo Específico Alto

<sup>2</sup>: Energía ahorrada al evitar los eventos de Consumo Específico Alto correctamente predichos

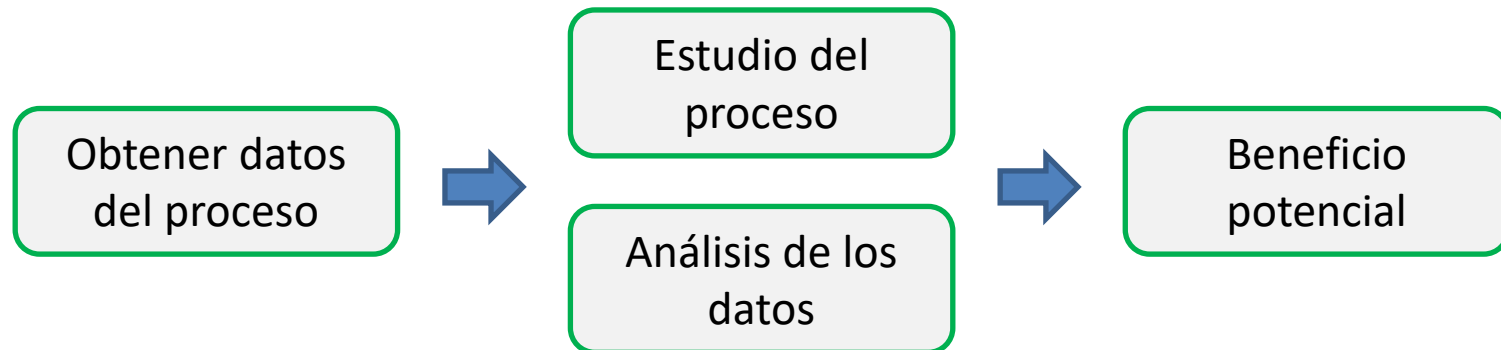
<sup>2</sup>: Precio monómico de energía: 80 USD/MWh



# Otras aplicaciones



¿Cómo saber si esta herramienta me sirve?



Las técnicas de machine Learning son capaces de modelar cualquier proceso complejo, permitiendo, por ejemplo:

- Predecir ineficiencias, comportamientos anómalos o fallas antes de que ocurran.
- Simular la respuesta de un proceso complejo ante variaciones en las entradas.
- Entrenamiento de personal en respuestas a situaciones de proceso.

## Modelo predictivo de CEE Alto:

- Permite producir ahorros reales al optimizar la operación del molino.

## Modelos de procesos mediante ML:

- Potente herramienta de apoyo para la toma de decisiones y mejora de la gestión operativa.
- Aplicables en etapas tempranas de proyectos, para descubrir y cuantificar oportunidades de ahorro.
- Poseen un amplio rango de aplicaciones: energía, predicción de fallas, simulación y entrenamiento.






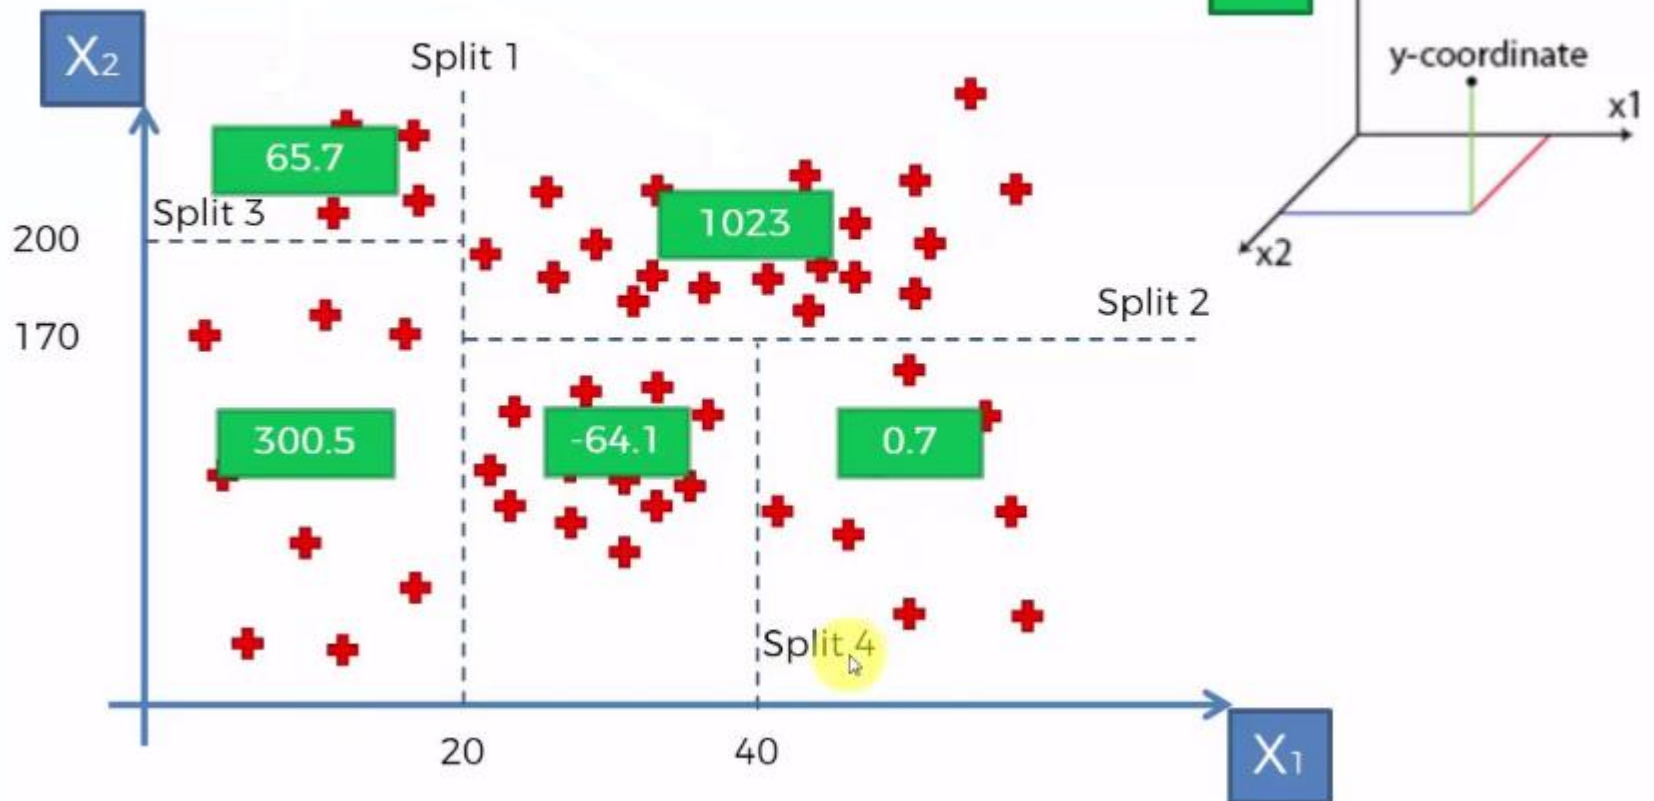

Machine Learning en minería

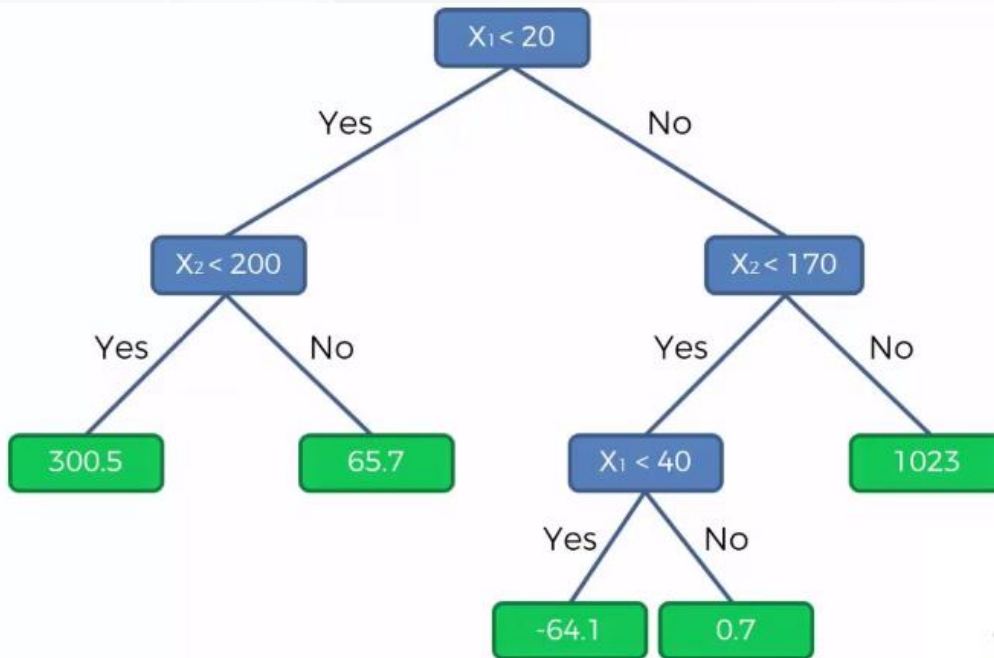
# Predicción del aumento del consumo específico de energía en Molinos SAG

**Juan Sepúlveda Cruz**  
[juansepulveda@jhg.cl](mailto:juansepulveda@jhg.cl)  
Ingeniero I+D  
JHG Ingenieria


# Anexos










Combinar todos los árboles generados



# Medir Precision y Recall no es trivial



# Resultados – Variables utilizadas en el Modelo



Descripción	tipo	valor
Tonelaje Correa 1-1 S1	variable	8,9%
Pre Desc Desc SAG1(descan	tendencia	7,6%
Consumo específico SAG 1	tendencia	6,1%
Indicador de Consumo específico alto	variable	5,0%
Consumo específico SAG 1	variable	4,9%
Potencia motores SAG 1	variable	4,4%
Cor.bba.alim.cicl.Bolas 1	variable	3,2%
Dens. alim. cicl. Bolas 1	variable	3,0%
%Sólido alim. SAG 1	variable	2,9%
Pre.Desc.Desc.SAG1(sala)	variable	2,9%
%Vel. Bba.alim.cicl.Bol 2	variable	2,8%
ALIMENTACIÓN CICLONES BOLAS 2	variable	2,7%
Pre Desc Desc SAG1(descan	variable	2,6%
Tonelaje Correa 1-2 S2	variable	2,5%
Tonelaje Correa 1-1 S1	tendencia	2,3%
Ton. correa 10-1 pebb. B1	variable	2,2%
ALIMENTACIÓN CICLONES BOLAS 1	variable	2,2%
Tonelaje Correa 8-2	tendencia	2,1%
ALIMENTACIÓN CICLONES BOLAS 2	tendencia	2,1%
Tonelaje Correa 8-2	variable	2,0%
Nivel 2 cuba desc. SAG 1	variable	2,0%
TONELAJE CORREA 9	variable	1,9%
Pulpa alim.cicl.l2 Bolas2	tendencia	1,9%
Pulpa alim.cicl.l2 Bolas2	variable	1,7%
Dens. alim. cicl. Bolas 1	tendencia	1,6%
Agua cuba descarga Bol.3	variable	1,6%
Granulometría CT 1-1 Promedio 10 minutos.0_525	tendencia	1,6%
Ton. correa 10-1 pebb. B1	tendencia	1,6%
Pre.Desc.Desc.SAG1(sala)	tendencia	1,6%
Agua cuba descarga Bol.3	tendencia	1,6%
Granulometría CT 1-1 Promedio 10 minutos.0_525	variable	1,5%
Nivel 2 cuba desc. SAG 1	tendencia	1,5%
%Sólido alim. SAG 1	tendencia	1,4%
TONELAJE CORREA 9	tendencia	1,4%
ALIMENTACIÓN CICLONES BOLAS 1	tendencia	1,3%
%Vel. Bba.alim.cicl.Bol 2	tendencia	1,3%
Tonelaje Correa 1-2 S2	tendencia	1,2%
Cor.bba.alim.cicl.Bolas 1	tendencia	1,0%

## Detección de Inchancables en minería:

Sistema de detección de elementos inchancables en punto de alimentación de chancador primario. El sistema esta basado en visión robótica e inteligencia artificial para la detección. Piloto en desarrollo.






## Detección de Inchancables en minería:



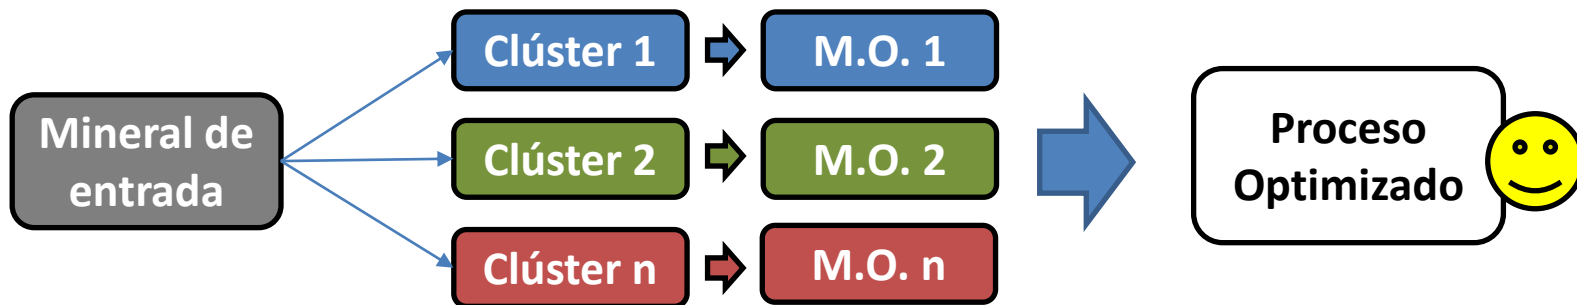
## Mantenimiento predictivo:

- Data histórica de los signos vitales de un equipo (temperatura, presión, etc.)
- Generar un modelo predictivo
- Calcular la probabilidad de falla del equipo y sugiere acción preventiva



## Optimización de proceso en minería:

A partir de la **información histórica** del comportamiento de un proceso, y dado un mineral de entrada, puedo identificar cuál es el **seteo óptimo** de variables de la planta que permitieron históricamente obtener el **mejor resultado operacional** (la mejor recuperación de cobre en el proceso de flotación)



Se genera la Tabla de “**clústers mineralógicos versus Modos de Operación**” que identifica los cuadrantes con recuperación histórica óptima, logrando significativas mejoras en los resultados finales.

## Camiones mineros autónomos:



Hemos logrado altos estándares de seguridad y de producción con el camión autónomo

- ✓ Reducción de riesgos de colisión
- ✓ Baja variabilidad en movimiento por hora
- ✓ Sobre 16 horas efectivas día caex

**Producción vs Plan**




**Horas Efectivas**



## Gestión energética en edificios

- IoT + Big Data Analytics
- Consumo de energía reducido 7%
- Identificación de oportunidades puntuales de ahorro y anomalías



## Predicción de generación para ERNC

- Predicción de la generación de plantas fotovoltaicas en función de las condiciones climáticas
- Detección de nubes y cuantificación de su impacto en la generación
- Permite prevenir al coordinador energético “bajones” de generación eléctrica

